


Lineare Regression


$$\pi_1 = \beta_0 + \beta_1 x$$

Logistische Regression (Logit-Modell)

$$\ln\left(\frac{\pi_1}{1 - \pi_1}\right) = \beta_0 + \beta_1 x$$



$$\beta_0=0; \beta_1=1$$



$$\beta_0=0; \beta_1=-1$$

Logit
(Log-Odd)

$$\ln\left(\frac{\pi_1}{1 - \pi_1}\right) = \beta_0 + \beta_1 x$$

Odd

$$\frac{\pi_1}{1 - \pi_1} = e^{\beta_0 + \beta_1 x} = e^{\beta_0} \times e^{\beta_1 x}$$

Wahrschein-
lichkeit

$$\pi_1 = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}$$

Zu den Transformationen

$$(1) \quad \ln\left(\frac{\pi_1}{1-\pi_1}\right) = \beta_0 + \beta_1 x$$

$$\text{da: } e^{\ln Q} = Q$$

$$(2) \quad e^{\ln(\pi_1/(1-\pi_1))} = \frac{\pi_1}{1-\pi_1} = e^{(\beta_0+\beta_1 x)} = e^{\beta_0} \times e^{\beta_1 x} \quad \big| \cdot (1-\pi_1)$$

$$(3) \quad \pi_1 = (1-\pi_1)e^{(\beta_0+\beta_1 x)}$$

$$(4) \quad \pi_1 = e^{(\beta_0+\beta_1 x)} - \pi_1 e^{(\beta_0+\beta_1 x)} \quad \big| + \pi_1 e^{(\beta_0+\beta_1 x)}$$

Zu den Transformationen (Fortsetzung)

$$(5) \quad \pi_1 + \pi_1 e^{(\beta_0 + \beta_1 x)} = e^{(\beta_0 + \beta_1 x)}$$

$$(6) \quad \pi_1 (1 + e^{(\beta_0 + \beta_1 x)}) = e^{(\beta_0 + \beta_1 x)} \quad \left| \div (1 + e^{(\beta_0 + \beta_1 x)}) \right.$$

$$(7) \quad \pi_1 = \frac{e^{(\beta_0 + \beta_1 x)}}{1 + e^{(\beta_0 + \beta_1 x)}}$$

EQUAL

Wenn sich die Einkommen in unserer Gesellschaft stärker angleichen würden: Versprechen Sie sich davon Vorteile? [**1**=ja; **0**=nein]

EK

Monatl. Haushaltsnettoeinkommen, dividiert durch die Zahl der Haushaltsmitglieder, die zu diesem Haushaltseinkommen beitragen

Codes der erfragten Einkommensklassen

1 = *unter* 1.000 DM

2, ..., 15 = 1.000 bis 8.000 DM, in Stufen à 500 DM

16 = *über* 8.000 DM

EQUAL

		Häufigkeit	Prozent	Gültige Prozente	Kumulierte Prozente
Gültig	,00	141	43,8	45,8	45,8
	1,00	167	51,9	54,2	100,0
	Gesamt	308	95,7	100,0	
Fehlend	System	14	4,3		
Gesamt		322	100,0		

Deskriptive Statistiken

	Mittelwert	Standardabweichung	N
EQUAL	,5432	,49903	278
EK	4,6640	2,55603	278

EK

	Häufigkeit	Prozent	Gültige Prozente	Kumulierte Prozente
Gültig				
,50	3	,9	1,0	1,0
1,00	10	3,1	3,4	4,5
1,25	1	,3	,3	4,8
1,50	9	2,8	3,1	7,9
2,00	24	7,5	8,3	16,2
2,33	2	,6	,7	16,9
2,50	13	4,0	4,5	21,4
2,67	2	,6	,7	22,1
3,00	27	8,4	9,3	31,4
3,33	1	,3	,3	31,7
3,50	23	7,1	7,9	39,7
3,67	3	,9	1,0	40,7
4,00	30	9,3	10,3	51,0
4,50	19	5,9	6,6	57,6
5,00	35	10,9	12,1	69,7
5,33	3	,9	1,0	70,7
5,50	8	2,5	2,8	73,4
6,00	16	5,0	5,5	79,0
6,50	5	1,6	1,7	80,7
7,00	15	4,7	5,2	85,9
7,50	3	,9	1,0	86,9
8,00	21	6,5	7,2	94,1
9,00	7	2,2	2,4	96,6
10,00	1	,3	,3	96,9
11,00	3	,9	1,0	97,9
12,00	1	,3	,3	98,3
13,00	1	,3	,3	98,6
14,00	1	,3	,3	99,0
16,00	3	,9	1,0	100,0
Gesamt	290	90,1	100,0	
Fehlend System	32	9,9		
Gesamt	322	100,0		

Lineare
Regression

Modellzusammenfassung

Modell	R	R-Quadrat	Korrigiertes R-Quadrat	Standardf ehler des Schätzers
1	,176 ^a	,031	,027	,49218

a. Einflußvariablen : (Konstante), EK

Koeffizienten^a

Modell	Nicht standardisierte Koeffizienten		Standardisie rte Koeffizienten	T	Signifikanz
	B	Standar dfehler	Beta		
1 (Konstante)	,703	,062		11,429	,000
EK	-3,426E-02	,012	-,176	-2,962	,003

a. Abhängige Variable: EQUAL

n=278

Logistische Regression

Modellzusammenfassung


Schritt	-2 Log-Likelihood	Cox & Snell R-Quadrat	Nagelkerkes R-Quadrat
1	374,590	,031	,041

Variablen in der Gleichung

		Regressions koeffizientB	Standar dfehler	Wald	df	Sig.	Exp(B)
Schritt	EK	-,144	,051	8,080	1	,004	,866
1	Konstante	,847	,266	10,160	1	,001	2,332

a. In Schritt 1 eingegebene Variablen: EK.

n=278



X	π (log)	π (lin)
0	0,7	0,7
1	0,67	0,67
3	0,60	0,60
5	0,53	0,53
7	0,46	0,47
9	0,39	0,40
11	0,32	0,33
13	0,26	0,26
15	0,21	0,19
17	0,17	0,13

Likelihood-Prinzip

Besagt, dass man aus der Menge der möglichen Parameter der Population denjenigen auswählen sollte, bei dem es am wahrscheinlichsten ist, dass man die vorliegende Stichprobe beobachtet.

$\Pr(f \mid \pi, n, M)$ Wenn **Verteilungsfunktion** M = Binomialverteilung:

$$\Pr(f \mid \pi, n) = \binom{n}{f} \pi^f (1 - \pi)^{n-f}$$

3 Gruppen (Populationen) á 10 Personen

G1: 3 von 10 haben gesuchte Eigenschaft

G2: 5 von 10 haben gesuchte Eigenschaft

G3: 8 von 10 haben gesuchte Eigenschaft

Es wird Stichprobe vom Umfang $n=3$ (mit Zurücklegen) gezogen;
alle 3 Personen hatten die gesuchte Eigenschaft ($f=3$)

Frage: aus welcher der 3 Gruppen stammt die Stichprobe?

$$\Pr(f|\pi, n) = \binom{n}{f} \pi^f (1 - \pi)^{n-f}$$

$$\Pr(3|\pi, 3) = \binom{3}{3} \pi^3 (1 - \pi)^{3-3}$$

$$\Pr(3|0,30,3) = \binom{3}{3} 0,30^3 (1 - 0,30)^{3-3} = \underline{\underline{0,027}}$$

$$\Pr(3|0,50,3) = \binom{3}{3} 0,50^3 (1 - 0,50)^{3-3} = \underline{\underline{0,125}}$$

$$\Pr(3|0,80,3) = \binom{3}{3} 0,80^3 (1 - 0,80)^{3-3} = \underline{\underline{0,512}}$$

$$\Pr(f \mid \pi, n, M) \quad \Pr(f \mid \pi, n) = \binom{n}{f} \pi^f (1 - \pi)^{n-f}$$

Likelihood-Funktion:

$$L(\pi \mid f, n, M) \quad L(\pi \mid f, n) = \binom{n}{f} \pi^f (1 - \pi)^{n-f}$$

$$L = K \pi^f (1 - \pi)^{n-f}$$

Zu maximieren: $\ln L = \ln(K) + f \ln \pi + (n - f) \ln(1 - \pi)$

Gütemaße

-2LL [Devianz] -2 × LogLikelihood

(entspricht Fehlerquadratsumme der linearen Regression)

Chi²-verteilt mit $df=N-K-1$

N = Anzahl der Beobachtungen

K = Anzahl der unabh. Variablen

H₀: Modell besitzt perfekte Anpassung

H₁: Modell besitzt keine perfekte Anpassung

Perfekter Modellfit: Likelihood=1, Devianz=0

$$McFaddens - R^2 = 1 - \frac{LL_V}{LL_0}$$

LL_0 : LogLikelihood des Nullmodells (nur mit Konstante)

LL_V : LogLikelihood des vollständigen Modells

$$Cox \& Snell - R^2 = 1 - \left[\frac{L_0}{L_V} \right]^{\frac{2}{N}}$$

L_0 : Likelihood des Nullmodells (nur mit Konstante)

L_V : Likelihood des vollständigen Modells

N : Stichprobenumfang

$$\text{Nagelkerke } R^2 = \frac{R^2}{R_{\max}^2}$$

$$R_{\max}^2 = 1 - \left(L_0\right)^{\frac{2}{N}}$$

L_0 : Likelihood des Nullmodells (nur mit Konstante)

N: Stichprobenumfang

Wald-Statistik

$$W = \left(\frac{b_k}{s_{b_k}} \right)^2$$

- asymptotisch Chi²-verteilt,
- bei df=1 Freiheitsgrad

Erweiterung um erklärende Variablen

$$\ln\left(\frac{\pi_1}{1-\pi_1}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$$

$$\frac{\pi_1}{1-\pi_1} = e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k} = e^{\beta_0} \times e^{\beta_1 x_1} \times e^{\beta_2 x_2} \times \dots \times e^{\beta_k x_k}$$

$$\pi_1 = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k}}$$

Polytome abhängige Variable

mit I Ausprägungen

Die $\frac{I \times (I-1)}{2}$ unterscheidbaren Odds bzw. Logits

sind durch $I - 1$ Modellgleichungen darzustellen.

z.B.:

$$\ln\left(\frac{\pi_1}{\pi_3}\right) = \beta_{0,1/3} + \beta_{1,1/3}x_1$$

$$\ln\left(\frac{\pi_2}{\pi_3}\right) = \beta_{0,2/3} + \beta_{1,2/3}x_1$$


Kategoriale unabhängige Variablen

Logit Modell

$$\ln\left(\frac{\pi_1}{1 - \pi_1}\right) = \ln\left(\frac{m_{q1}}{m_{q2}}\right) = \beta_0 + \beta_1 x_{1q}$$

Loglineares Modell:

$$\ln(m_{ql}) = \lambda + \lambda_q^X + \lambda_l^Y + \lambda_{ql}^{XY}$$



Zur Äquivalenz von loglinearen und Logit Modellen:

$$\ln\left(\frac{m_{q1}}{m_{q2}}\right) = \beta_0 + \beta_1 x_q = 2\lambda_1^Y + 2\lambda_{q1}^{XY} \quad \text{wenn: } \underline{\lambda_1^Y = -\lambda_2^Y} \quad \text{und} \quad \underline{\lambda_{q1}^{XY} = -\lambda_{q2}^{XY}}$$

$$\ln\left(\frac{m_{q1}}{m_{q2}}\right) = \ln(m_{q1}) - \ln(m_{q2})$$

$$\ln(m_{q1}) = \lambda + \lambda_q^X + \lambda_1^Y + \lambda_{q1}^{XY}$$

$$\ln(m_{q2}) = \lambda + \lambda_q^X + \lambda_2^Y + \lambda_{q2}^{XY}$$

$$\begin{aligned} \ln(m_{q1}) - \ln(m_{q2}) &= \lambda - \lambda + \lambda_q^X - \lambda_q^X + \lambda_1^Y - \lambda_2^Y + \lambda_{q1}^{XY} - \lambda_{q2}^{XY} \\ &= \lambda_1^Y - (-\lambda_1^Y) + \lambda_{q1}^{XY} - (-\lambda_{q1}^{XY}) = 2\lambda_1^Y + 2\lambda_{q1}^{XY} \end{aligned}$$

	d=1	d=2	d=3		d=1	d=2
q=1	1	0	0		1	0
q=2	0	1	0		0	1
q=3	0	0	1		-1	-1

Dummykodierung Effektkodierung